

DOI: 10.19650/j.cnki.cjsi.12311773

基于三维坐姿的压力数据自动标注方法^{*}

郑台台, 姚燕, 蔡晋辉

(中国计量大学计量测试工程学院 杭州 310018)

摘要:针对当前传统坐姿标注方法,存在操作繁琐、人工标注效率低等问题,提出了一种基于三维坐姿的压力数据自动标注方法。该方法基于双指针时间戳匹配实现双目视觉数据和压力数据同步实时采集;采取归一化、自适应中值滤波处理压力数据,去除压力数据量纲影响和尖峰噪声;利用二维姿态估计与匹配优化、坐标变换和多点三角测量处理视觉数据,提取6个三维人体关键点信息;构造基于坐姿特征的骨架图和基于邻接节点间空间三维投影角度特征,建立一个基于三维坐姿的标注信息生成模型;利用标注信息标注压力数据,构建带标注的坐姿压力数据集。实际应用中,单个样本数据对视觉-压力端采集平均时间差仅为21 ms,生成标注准确率达98.98%,自动标注平均耗时0.199 s,标注速度较人工标注提升13.3倍。

关键词: YOLOv7-Pose; 阵列式压力传感器; 图卷积网络; 自动标注

中图分类号: TP391 TH701 **文献标识码:** A **国家标准学科分类代码:** 520.60

Automatic annotation method for pressure data based on three-dimensional sitting posture

Zheng Taitai, Yao Yan, Cai Jinhui

(College of Metrology & Measurement Engineering, China Jiliang University, Hangzhou 310018, China)

Abstract: To address the problems of cumbersome operation and low efficiency of manual annotation in current traditional sitting posture annotation methods, this article proposes an automatic annotation method for pressure data based on three-dimensional sitting posture. Real time synchronous collection of binocular visual data and pressure data based on dual pointer timestamp matching. The normalization and adaptive median filtering are utilized to process pressure data, and remove the dimensional influence and peak noise of pressure data. By using 2D pose estimation and matching optimization, coordinate transformation, and multi-point triangulation to process visual data, 6 key point information of the 3D human body are extracted. A skeleton image based on sitting posture features and a 3D projection angle feature between adjacent nodes are constructed, and a 3D sitting posture based annotation information generation model is formulated. The annotation information is utilized to label the pressure data and create an annotated sitting pressure dataset. In practical applications, the average time difference between real-time synchronous collection of single sample data is only 21 ms, and the accuracy of label generation is 98.98%. The average time for automatic labeling is 0.199 s, and the labeling speed is 13.3 times faster than manual labeling.

Keywords: YOLOv7-Pose; array pressure sensor; graph convolutional network; automatic dimension

0 引言

研究表明,人们日常办公、学习会花大量时间在座椅上,这会增加可能遭受由长期不良坐姿引起的肌肉和骨骼疾病的风险^[1]。坐姿识别的研究对于改善人们的坐姿习惯和纠正不良坐姿具有重要意义。

传统的坐姿识别主要由机器视觉方法^[2]为主,如 Li 等^[3]基于人体姿势变化的角度,提出了一种基于骨骼图多尺度时空特征的异常姿势识别方法,利用时空图卷积模块作为特征提取单元,提出了一种基于图卷积网络的多尺度时空特征提取模型,取得了不错的效果。叶启朗等^[4]提出一种基于人体骨架的任意角度坐姿识别方法,

对任意角度坐姿进行正面骨架图估计,并输出预测概率。虽然机器视觉方法具有识别精度高、可以提取多角度更充分的数据特征等优点。但存在视觉传感器对环境条件的依赖^[5],侵犯个人隐私、涉及遮挡影响等问题,难以实际应用于坐姿识别领域。基于压力传感器进行坐姿信息的采集,具有不依赖外部环境、对压力特征变化敏感和非侵入等优势^[6],近年来成为坐姿识别领域的热点研究方向。基于压力传感器的坐姿识别研究十分广泛,如 Ran 等^[7]利用压力传感器阵列收集坐姿相关信息,使用 5 层人工神经网络进行识别,并进一步优化了传感器尺寸。Cai 等^[8]实现了一种基于柔性阵列压力传感器的坐姿识别系统,提出一种改进的基于自组织图(improved self-organizing map, ISOM)的坐姿识别算法,实验证明该算法具有良好的鲁棒性和较高的精度。但要保证坐姿识别的普适性和准确性,需要模型对大量可靠的压力视觉进行训练。传统的坐姿数据集标注主要倚靠人工标注,需要专业人员观察和记录个体的坐姿姿态。然而,这种方式存在采集过程繁琐、人工标注耗时等问题,限制了大规模数据采集和标注的效率。周佳裕等^[9]提出接触式交互感知的人体三维坐姿姿态估计方法,仅凭借压力数据可以有效估计人体坐姿的三维关键点,但直接将模型估计的人体坐姿三维关键点用于坐姿预测效果不佳。

基于上述问题,结合机器视觉方法和压力传感器方法的优点,提出一套基于三维坐姿的压力数据自动标注方法。所提方法包括系统设计、数据采集、数据处理、标注生成和压力数据自动标注,此方法具有操作简单、使用方便、被测人员体型因素影响较小等优点,采用自动标注方法所需耗时远快于人工标注,提高坐姿标注的效率。

1 自动标注系统总体设计与实验搭建

1.1 总体设计

设计基于三维坐姿的压力数据自动标注系统,其总体流程如图 1 所示。双目相机获取实时视觉数据,压力传感器获取实时压力数据,为每一帧数据添加时间戳;基于双指针时间戳匹配算法对视觉-压力数据进行同步优化;利用二维姿态估计算法提取视觉数据中关键点特征的像素坐标,并对提取数据进行匹配优化;利用三角测量和坐标变换,获取阵列式传感器坐标系下人体关键点的三维坐标;优化三维坐姿无向骨架图,基于邻接节点间三维投影角度构造节点特征,构建基于三维坐姿的标注生成模型;对预处理后的压力数据进行标注。




图1 总体流程

Fig. 1 Overall process

1.2 数据采集系统搭建

搭建数据采集系统,以获取坐姿压力数据和视觉图像数据,系统框架如图 2 所示。

其中,视觉传感器选用 2 台同型号的工业相机,使用前需要先对 2 台相机进行双目标定,双目标定是用于确

定双目相机系统的内部参数、外部参数,消除视差影响。通过应用张正友标定方法^[10]和图像角点的重投影误差优化标定图像对^[11],选取 25 组标定图片的内参数矩阵以及相机之间的旋转矩阵和平移向量,建立二维图像坐标与相机坐标系之间的映射关系。




图 2 数据采集系统框架

Fig. 2 Data collection system framework

压力传感器选用 MF-6060 阵列式压力薄膜传感器, 坐姿压力与传感器电阻的倒数呈近似线性变化, 通过采集电路获取压力数据转换的电压值, 每秒采集 60×60 共 3 600 个压力点数据。

2 基于三维坐姿的压力数据自动标注方法

2.1 基于双指针的数据对时间戳匹配

双目相机使用硬同步技术实现相机端同步采集, 为了获取更准确的数据对匹配, 需要双目视觉数据和压力数据对近似实时同步。双目相机采样频率设置为 5 Hz, 压力传感器的采样频率设置为 10 Hz, 为每一帧数据添加时间戳, 提出基于双指针的数据对时间戳匹配算法挑选最小误差数据对, 保持数据对采集的实时性, 公式如下:

$$(I_i^l, I_i^r, v_i) = \begin{cases} (I_{j+k}^l, I_{j+k}^r, v_j), & t(I_j^l) < t(v_j) \\ (I_j^l, I_j^r, v_{j+k}), & t(I_j^l) > t(v_j) \end{cases} \quad (1)$$

式中: (I_j^l, I_j^r, v_j) 是第 j 组实时采集的数据对; $t(I_j^l)$ 、 $t(I_j^r)$ 是第 j 组视觉数据 I^l 、 I^r 所对应的采集时间戳; $t(v_j)$ 是第 j 组压力数据对应的采集时间戳; k 为最优匹配序号。如果 $t(I_j^l) < t(v_j)$, $|t(I_{j+k}^l) - t(v_j)| = \min(|t(I_{j+k_1}^l) - t(v_j)|)$; $t(I_j^l) > t(v_j)$, $|t(I_j^l) - t(v_{j+k})| = \min(|t(I_j^l) - t(v_{j+k_2})|)$ 。其中, $k_1 \in \{0, 1, 2\}$, $k_2 \in \{0, 1, 2, 3, 4\}$ 。基于双指针的数据对时间戳匹配方法示意图如图 3 所示。




图 3 基于双指针的数据对时间戳匹配示意图

Fig. 3 Diagram of data pair timestamp matching based on double pointers

2.2 阵列式压力数据预处理

不同的实验对象, 传感器感受的相对压力分布不同。阵列式传感器采集数据时, 也会记录一些数据噪声, 如拉升刺激、闪烁噪声、机械噪声等^[12], 为消除量纲影响和去除压力噪声, 添加数据进程用于数据采集进程结束后进行压力数据预处理, 具体表现为, 对获取的压力数据先进行归一化, 再进行滤波处理:

$$v'_{i,k} = \frac{v_{i,k} - v_{\min}}{v_{\max} - v_{\min}} \quad (2)$$

$$v''_i = \text{filter}(v'_i) \quad (3)$$

式中: $v_{\max}$ 和 $v_{\min}$ 分别表示压力传感器接收数据的最大值和最小值; $v_{i,k}$ 表示第 i 组的数据中第 k 个压力点的数据值; $\text{filter}(x)$ 为滤波函数。

2.3 视觉数据预处理

1) 坐标变换与优化

方便三角测量计算和优化, 先将左相机和右相机的像素坐标系分别转换为左、右相机的相机坐标系, 对于任意匹配的数据对, 以左相机坐标系为例, 计算公式为:

$$\begin{bmatrix} u_c^l \\ v_c^l \\ 1 \end{bmatrix} = K^l \begin{bmatrix} E_{3 \times 3} & \mathbf{0} \\ \mathbf{0} & 1 \end{bmatrix} \begin{bmatrix} X_c^l \\ Y_c^l \\ Z_c^l \\ 1 \end{bmatrix} \quad (4)$$

$$\begin{bmatrix} u_{i,c}^l \\ v_{i,c}^l \\ 1 \end{bmatrix} = K^l \begin{bmatrix} R_{3 \times 3} & T_{3 \times 1} \\ \mathbf{0} & 1 \end{bmatrix} \begin{bmatrix} X_{i,c}^l \\ Y_{i,c}^l \\ Z_{i,c}^l \\ 1 \end{bmatrix} \quad (5)$$

式中: $[X_c^l, Y_c^l, Z_c^l]$ 是关键点 c 在左相机坐标系下的坐标; 在任意匹配的数据对图像 I^l 和 I^r 中, (u_c^l, v_c^l) 、 (u_c^r, v_c^r) 分别对应关键点 c 在左相机和右相机的像素坐标系下的坐标; $E_{3 \times 3}$ 为单位矩阵; K^l 和 K^r 分别是左、右相机的内参矩阵; $R_{3 \times 3}$ 和 $T_{3 \times 1}$ 分别是右相机坐标系变换到左相机坐标系的旋转矩阵和平移矩阵。 K^l 、 K^r 、 $R_{3 \times 3}$ 和 $T_{3 \times 1}$ 这 4 个参数矩阵均由双目标定可得。其中:

$$K^l = \begin{bmatrix} f_{x_l} & 0 & u_{0_l} & 0 \\ 0 & f_{y_l} & v_{0_l} & 0 \\ 0 & 0 & 1 & 0 \end{bmatrix}$$

$$K^r = \begin{bmatrix} f_{x_r} & 0 & u_{0_r} & 0 \\ 0 & f_{y_r} & v_{0_r} & 0 \\ 0 & 0 & 1 & 0 \end{bmatrix}$$

由于拍摄距离和拍摄角度的不同会导致关键点三维坐标产生差异, 需要将获取的左、右相机坐标系下的关键点三维坐标转换成阵列式压力传感器世界坐标系下的关键点三维坐标。对于任意匹配的数据对, 其计

算公式为:

$$\begin{bmatrix} X_c^l \\ Y_c^l \\ Z_c^l \\ 1 \end{bmatrix} = \begin{bmatrix} \mathbf{R}'_{3 \times 3} & \mathbf{T}'_{3 \times 1} \\ \mathbf{0} & \mathbf{1} \end{bmatrix} \begin{bmatrix} X_c^{w,l} \\ Y_c^{w,l} \\ Z_c^{w,l} \\ 1 \end{bmatrix} \quad (6)$$

式中: $[X_c^l, Y_c^l, Z_c^l]$ 是点 c 在左相机坐标系下的三维坐标; $[X_c^{w,l}, Y_c^{w,l}, Z_c^{w,l}]$ 是点 c 在左相机坐标系转换到世界坐标系下的三维坐标; $\mathbf{R}'_{3 \times 3}$ 和 $\mathbf{T}'_{3 \times 1}$ 分别是相机坐标系转换到座椅坐标系的旋转矩阵和平移向量。

分别获取点 c 在左、右相机坐标系转换到世界坐标系下的三维坐标,并求取加和平均值作为点 c 在世界坐标系下的三维坐标:

$$\begin{aligned} X_c^w &= (X_c^{w,l} + X_c^{w,r})/2 \\ Y_c^w &= (Y_c^{w,l} + Y_c^{w,r})/2 \\ Z_c^w &= (Z_c^{w,l} + Z_c^{w,r})/2 \end{aligned} \quad (7)$$

式中: $[X_c^{w,r}, Y_c^{w,r}, Z_c^{w,r}]$ 是点 c 在右相机坐标系转换到世界坐标系下的三维坐标; $[X_c^w, Y_c^w, Z_c^w]$ 是最终输出的世界坐标系下三维坐标。

2) 基于双目相机的三维姿态标签生成

当要求标注系统实现自动标注时,二维坐姿估计应在确保高准确率的前提下,保持识别速度,以满足实时标注的需求。YOLOv7-Pose 是一种先进的人体姿态识别深度学习模型,它是基于 YOLO 目标检测框架的进一步改进和扩展^[13]。经过大规模人体姿态数据集的充分训练和验证,确保具备出色的泛化性能和姿态识别准确度^[13]。

利用 YOLOv7-Pose 做二维姿态估计,可能存在关键点遮挡识别不准、人体移动过快导致左、右相机视觉数据中识别关键点位置不匹配,本文利用左、右相机获取图像的近似对称性,提出二维姿态估计匹配优化算法,去除异常匹配图像对。如图 4 所示,由 YOLOv7-Pose 分别获取图像 I^l 和 I^r 目标检测框的二维坐标,对于任意的匹配数对,目标检测框几何尺寸计算公式为:

$$h^l = (u_0^l, v_1^l), w^l = v_0^l - v_2^l \quad (8)$$

$$h^r = (u_0^r, v_1^r), w^r = v_0^r - v_2^r$$

式中: (u_c^l, v_c^l) 、 (u_c^r, v_c^r) 分别是图 4 中第 c 个关键点在图像 I^l 和 I^r 像素坐标系下的坐标值。获取图像对目标检测框几何尺寸后,研究图像对几何关系,其计算公式为:

$$f^l = \frac{h^l}{w^l}, f^r = \frac{h^r}{w^r} \quad (9)$$

$$f^{ratio} = f^l / f^r$$

式中: f^l 和 f^r 是目标检测框的高宽比; f^{ratio} 是图像对目标检测框高宽比的比值。由实验可得,正常匹配图像对情情况下, $|f^{ratio} - 1|$ 平均值为 0.065、极大值为 0.187。选取

$|f^{ratio} - 1|$ 的正常匹配阈值为 0.2, 当 $|f^{ratio} - 1| > 0.2$ 时,删除异常匹配图像对。




图4 YOLOv7-Pose 输出关键点

Fig. 4 YOLOv7 Pose output key

在两个不同视角的二维图像中找到对应的坐标点。通过对极几何模型^[14],考虑相机 I^l 和相机 I^r ,它们之间的运动表示为 $\mathbf{R}$ 和 $\mathbf{T}$,相机的光心分别为 O^l 和 O^r 。结合坐标变换,利用三角测量^[14]分别计算左、右相机坐标系下对应关键点的三维坐标。

2.4 三维坐姿标注生成模型

1) 骨架图节点和特征构建

Kipf 等^[15]提出了一种用于图结构数据的图卷积网络(graph convolutional network, GCN)。通过在节点之间建立连接并利用节点特征来学习节点表征,提取更丰富的图结构特征^[15]。Yan 等^[16]通过提取骨骼关键节点间的空间特征,构造了骨架图特征,并首次应用于图卷积网络进行人体动作识别。通常根据人体物理连接边关系构建连接矩阵,构建骨架图 $G = (D, L)$,其中节点集 $D = \{d_i | i = 0, \dots, N\}$ 包含了所有人体关键点,边集 L 表示节点无向连接边,邻接矩阵 $\mathbf{A}$ 可以构造为:

$$A_{ij} = \begin{cases} 1, & (d_i, d_j) \in L \\ 0, & \text{其他} \end{cases} \quad (10)$$

对于静态人体姿态识别,不同体型对识别效果影响较大,基于人体姿势的角度变化,提出基于邻接节点空间三维投影角度作为节点特征,节点构造如图 5 所示。

其计算公式为:

$$\begin{aligned} [\theta_{i,j}^1, \theta_{i,j}^2] &= \left[p \times \tan^{-1} \left(\frac{x_i - x_j}{z_i - z_j} \right), \right. \\ &\quad \left. p \times \tan^{-1} \left(\frac{y_i - y_j}{z_i - z_j} \right) \right] \end{aligned} \quad (11)$$

$$h_i = \sum_j [\theta_{i,j}^1, \theta_{i,j}^2] + (n - \sum_j A_{ij}) \times [0, 0], j \in L_i \quad (12)$$

式中: (x_i, y_i, z_i) 是节点 i 的三维坐标; p 是常数, $p = 180/\pi$; L_i 是与节点 i 相邻节点组成的集合; $\theta_{i,j}^1$ 和 $\theta_{i,j}^2$ 分别是相邻节点 i 与节点 j 投影到 xoz 、 yo 平面上的相连直线与 z 轴的夹角; h_i 是节点 i 所对应的节点特征矩阵,由邻




图 5 节点特征构造示意图

Fig. 5 Diagram of node feature construction

接节点空间三维投影角度特征组成, n 为最大邻接节点数, $\mathbf{h}_i$ 的维度为 $2n \times 1$, 邻接节点数少于 n 时矩阵剩下维度补充 0 值。

对比直接选用 19 个关键点的三维坐标特征, 对不同体型的被测人员构成的测试集进行预测, 表 1 为模型预测准确率。

表 1 测试集构成人数对节点特征的影响

Table 1 The impact of the number of test set members on node characteristics

节点特征	预测准确率				
	2	3	4	5	6
三维坐标/%	93.32	91.18	89.98	85.85	83.25
投影角度/%	94.23	94.1	93.85	93.35	92.7

2) 模型结构

图注意力网络 (graph attention networks, GAT) 是一种用于图结构数据的注意力机制扩展^[17]。它通过为每个节点学习动态的权重, 自适应地对节点邻居的特征进行加权聚合。结合 GCN 和 GAT, 通过多层卷积操作逐步传播和聚合节点特征, 以扩大感受野并增强特征表达能力, 同时学习多个不同的注意力权重, 关注节点之间的不同关系和特征组合, 提升模型的非线性能力和表达能力, 具体模型结构如图 6 所示。




图 6 模型结构

Fig. 6 Model structure diagram

其中, 用于标注生成的算法网络由 3 层图卷积层和 1 层全局最大池化层组成, 并在每 2 层图卷积层中加入 1 层多头图注意力层提高模型的特征聚合能力。经过图卷积网络特征聚合后, 对节点特征进行全局最大池化操作, 将图中的节点特征池化为一个固定大小的全局特征向量, 利用全连接层将特征向量映射到所需的输出维度, 并输出预测坐姿。

3 实 验

3.1 实验环境及评价指标

本文实验基于 Windows10 环境开展, 处理器为 i7-7700HQ, 内存为 24 G。编程语言为 Python3.9, 深度学习框架基于 Pytorch1.9。使用模型训练时, 初始学习率设置为 0.001, 迭代轮次 epoch 设置为 30, 每次处理数据 batch 为 60。

本文选取准确率 (accuracy) 作为模型效果评价指标, 代表分类正确的样本数与样本总数的比例, 计算公式为:

$$accuracy = \frac{\sum_{j=1}^M \sum_{i=1, i \neq j}^M \frac{m_{i,j} + m_{i,i}}{m_{j,j} + m_{i,j} + m_{i,i} + m_{j,i}}}{N} \quad (13)$$

式中: M 表示类别的数量; $m_{i,j}$ 表示真实标签为 j 类, 被预测为 j 类的数量; $m_{i,i}$ 表示真实标签是 i 类, 被预测为 j 类的数量; N 表示所有的样本总数。

3.2 三维标注坐姿数据集获取

选取 10 位被测人员, 利用自动标注系统进行实时数据采集, 每位被测人员在座椅上以不停的速率运行, 左、右相机同步采集 67 500 组视觉数据。通过数据处理保留 66 599 组视觉数据, 构成三维标注坐姿数据集。将坐姿数据分为训练集和测试集, 其中训练集为 53 200 组数据, 测试集为 13 399 组数据, 用于训练、测试三维标注生

成模型。采集坐姿分为前倾、正坐、后倾、左倾、右倾、左翘二郎腿和右翘二郎腿 7 种坐姿,如图 7 所示。




图 7 各类坐姿示意图

Fig. 7 Diagram of various sitting positions

3.3 三维坐姿标注生成模型优化及分析

1) 基于坐姿特征的关键点优化

利用中心插值计算肩部中心和髋部中心关键点,与姿态估计模型输出的 17 个人体关键点组成人体关键点集合,计算 19 个人体关键点的关节间投影角度数据,会增加模型的冗余,降低模型的预测精度。人体关键点具有对称性,考虑对称选取不同的关键点组合,优化组合关键点数量提高坐姿预测的准确率。

如图 8 所示,伴随卷积层数的增加,模型准确率有所上升,当卷积层数增加到 5 层时,模型可能出现过拟合现象,准确率显著下降。当减少部分与坐姿相关度较低的关键点数量时,模型准确率有一定提升。但当组合关键点数量为 4 时,坐姿特征表达不全,预测准确率有所下降。选用 6 个关键点的节点组合和 3 层卷积层数,作为本文优化的骨架图节点和模型卷积层数。优化 YOLOv7-




图 8 不同关键点组合对模型影响

Fig. 8 The impact of different key point combinations on the model

Pose 模型,模型输出 6 个人体关键点和 4 个目标检测框的坐标,如图 9 所示。




图 9 优化后的 YOLOv7-Pose 关键点输出

Fig. 9 Optimized YOLOv7 Pose key point output

2) 模型注意力添加及骨架图优化

选取合适的节点组合后,提高模型特征聚合能力,添加多头注意力层,研究添加注意力层对模型影响。如图 10 所示,卷积层数为 3,未添加注意力层准确率为 97.25%,添加 2 层多头注意力层,预测准确率达 98.38%,提高了 1.13%,其各类坐姿预测热力图如图 11(a) 所示。通常根据人体物理连接边关系构建连接矩阵,但只考虑物理连接边的骨架图,对翘二郎腿等特征表达不够充分如图 11(b) 所示,连接左脚踝和右脚踝关键点,使得骨架图网络能够更好聚合脚部关键点的节点信息,改进后,模型在测试集上准确率达 98.97%。




图 10 添加注意力层对模型影响

Fig. 10 The influence of attention layer on the model

各类坐姿下优化的三维坐姿特征骨架图如图 12 所示。

3.4 基于三维坐姿的压力数据自动标注优化与分析

1) 基于双指针时间戳同步匹配算法优化

本文设计了基于双指针时间戳同步匹配算法,用于实现双目相机和阵列式压力传感器数据的同步采集。研究采样频率变化和匹配算法对数据匹配时间差的影响,利用 3 种不同采样频率的采集方法进行对比,方法 1 为视觉-压力数据采样频率均设置为 10 Hz 且不进行算法匹配;方法 2 为视觉-压力数据采样频率均设置为 5 Hz 且不进行算法匹配;方法 3 为本文提出的方法,分别采集




图 11 坐姿预测热力图

Fig. 11 Thermogram for predicting sitting posture




图 12 不同坐姿下优化的三维坐姿特征骨架图

Fig. 12 Optimized 3D sitting feature skeleton maps for different sitting positions

5 000 组视觉数据对和同时获取的压力数据,结果如表 2 所示。

表 2 不同采样频率的采集方法对比

Table 2 Comparison of collection methods with different sampling frequencies			
评价指标	方法 1	方法 2	本文方法
平均时间差/ms	43	32	21
输出数据/组	5 000	5 000	4 776

由表 2 可知,基于双指针时间戳同步匹配算法输出

4 776 组视觉-压力数据对,剔除了部分不匹配数据,实现较小的时间戳平均时间差,使自动标注模型获取的数据更具可靠性。

2) 压力数据滤波算法选取

针对本文同步匹配算法优化后的 4 776 组视觉-压力数据对,提取压力数据,研究不同滤波算法对压力数据的影响,采用峰值信噪比 (peak signal-to-noise ratio, PSNR)^[18]对压力数据的滤波效果进行评价,其计算公式为:

$$PSNR_i = 10 \lg \frac{3\,600}{\sum_{k=0}^{3\,599} (v''_{i,k} - v'_{i,k})^2}$$

(14)

式中: $PSNR_i$ 是第 i 组压力数据的 PSNR; $v'_{i,k}$ 是归一化后第 i 组压力数据的第 k 个压力点数值; $v''_{i,k}$ 是滤波后第 i 组压力数据的第 k 个压力点数值。

表 3 为均值滤波、高斯滤波、双边滤波、中值滤波和自适应中值滤波 5 种不同滤波算法处理 4 776 组压力数据的平均 PSNR, 其中自适应滤波算法的 PSNR 最低, 说明自适应滤波后的图像更加接近原始图像^[19]。如图 13 所示, 自适应滤波不仅能很好保留图像数据的原始轮廓, 还能滤除数据突变值, 整体表现效果较好。因此, 本文选用自适应中值滤波滤除噪声。

表 3 不同滤波算法处理的平均 PSNR

Table 3 Average peak signal-to-noise ratio processed by different filtering algorithms					
评价指标	均值滤波	高斯滤波	双边滤波	中值滤波	自适应中值滤波
平均 PSNR	-11.94	-9.96	-9.43	-11.49	-8.25




图 13 不同滤波函数效果对比

Fig. 13 Comparison of the effects of different filtering functions

3) 自动标注效果对比

为了展示自动标注获取坐姿标签的实际效果, 获取上文利用本文方法处理后的 4 776 组视觉-压力数据对, 预先采用人工标注, 将人工标注的标签作为真实标签, 通过自动标注模型生成预测标签, 并标注压力数据。对比真实标签与预测标签, 验证自动标注系统实际应用的效果, 如表 4 所示。

由表 4 可知, 采用人工标注, 单个样本平均耗时 2.632 s; 采用自动标注, 单个样本平均耗时 0.199 s, 标注速度提升 13.3 倍, 标注生成准确率可达 98.98%, 自动标注效果明显。

表 4 人工标注与自动标注耗费时间表
Table 4 Schedule of manual and automatic annotation costs

评价指标	人工标注	自动标注		
		数据采集	数据处理	标注生成及自动标注
耗费时间	2.632	9.041×10^{-4}	0.198	1.044×10^{-3}

4 结 论

本文提出的基于三维姿态的压力数据自动标注方法, 通过视觉传感器和压力传感器分别提取视觉数据和压力数据, 利用基于双指针的时间戳匹配同步视觉-压力数据对, 并对匹配后的数据进行预处理。使用基于三维坐姿的标注生成模型对三维关键点进行坐姿预测, 并根据预测坐姿对匹配的压力数据进行自动标注。本文方法构造了邻接节点间投影角度作为节点特征, 降低了实验人员体型差异对模型的影响。实验证明, 通过本文方法进行自动标注, 弥补了手动标注效率低下、操作繁琐等缺陷。未来工作主要着手于对更加复杂的坐姿研究标注方法, 增加压力数据集样本, 通过自动标注的压力图像开展进一步的坐姿识别研究。

参考文献

[1] 郑泽铭. 人的坐姿检测方法 & 行为劝导研究[D]. 杭州: 浙江大学, 2013.
ZHENG Z M, Sitting posture sensing and healthy behavior persuasion[D]. Hangzhou: Zhejiang University, 2013.

[2] NEWELL A, YANG K, DENG J. Stacked hourglass networks for human pose estimation [C]. Computer Vision-ECCV 2016, PT VIII, 2016, 9912: 483-499.

[3] LI L, YANG G, LI Y, et al. Abnormal sitting posture recognition based on multi-scale spatiotemporal features of skeleton graph[J]. Engineering Applications of Artificial Intelligence, 2023, 123: 106374.

[4] 叶启朗, 李戴薪, 南海. 一种基于人体骨架的任意角度坐姿识别方法[J]. 计算机应用研究, 2023, 40(11): 3509-3514.
YE Q L, LI D X, NAN H. A method for recognition of arbitrary angle sitting posture based on human skeleton[J]. Application Research of Computers, 2023, 40(11): 3509-3514.

[5] LIU S, YIN Y, OSTADABBAS S. In-bed pose estimation: Deep learning with shallow dataset[J]. IEEE Journal of Translational Engineering in Health and Medicine, 2019(7): 4900112.

- [6] WAN Q, ZHAO H, LI J, et al. Hip positioning and sitting posture recognition based on human sitting pressure image[J]. *Sensors*, 2021, 21(2): 426.
- [7] RAN X, WANG C, XIAO Y, et al. A portable sitting posture monitoring system based on a pressure sensor array and machine learning[J]. *Sensors and Actuators A: Physical*, 2021, 331: 112900.
- [8] CAI W, ZHAO D, ZHANG M, et al. Improved self-organizing map-based unsupervised learning algorithm for sitting posture recognition system[J]. *Sensors*, 2021, 21(18): 6246.
- [9] 周佳裕, 蔡晋辉, 章乐, 等. 接触式交互感知的人体三维坐姿姿态估计[J]. *仪器仪表学报*, 2022, 43(11): 132-141.
- ZHOU J Y, CAI J H, ZHANG L, et al. Three-dimensional sitting posture estimation of human body based on contact interactive perception[J]. *Chinese Journal of Scientific Instrument*, 2022, 43(11): 132-141.
- [10] ZHANG Z. A flexible new technique for camera calibration[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2000, 22(11): 1330-1334.
- [11] DELAUNOY A, PRADOS E, PIRACÉS P G I, et al. Minimizing the multi-view stereo reprojection error for triangular surface meshes[C]. *BMVC 2008-British Machine Vision Conference*, 2008: 1-10.
- [12] ISHAC K, SUZUKI K. LifeChair: A conductive fabric sensor-based smart cushion for actively shaping sitting posture[J]. *Sensors*, 2018, 18(7): 2261.
- [13] WANG C Y, BOCHKOVSKIY A, LIAO H Y M. YOLOv7: Trainable bag-of-freebies sets new state-of-the-art for real-time object detectors[C]. *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 2023: 7464-7475.
- [14] HARTLEY R, ZISSERMANA. Multiple view geometry in computer vision[M]. Cambridge: Cambridge University Press, 2004.
- [15] KIPF T N, WELING M. Semi-supervised classification with graph convolutional networks[C]. *International Conference on Learning Representations*, 2017.
- [16] YAN S, XIONG Y, LIN D. Spatial temporal graph convolutional networks for skeleton-based action recognition[C]. *Proceedings of the AAAI Conference on Artificial Intelligence*, 2018.
- [17] VELIČKOVIĆ P, CUCURULL G, CASANOVA A, et al. Graph attention networks[C]. *International Conference on Learning Representations*, 2018.
- [18] WAN B, FANG Y, XIA X, et al. Weakly supervised video anomaly detection via center-guided discriminative learning[C]. *2020 IEEE international conference on multimedia and expo (ICME)*, IEEE, 2020: 1-6.
- [19] 贾宇申, 蔡振江, 程曼. 针对纵向纹理的图像自适应滤波算法[J]. *电子测量与仪器学报*, 2017, 31(3): 443-447.
- JIA Y SH, CAI ZH J, CHENG M. Image adaptive filtering algorithm for longitudinal textures[J]. *Journal of Electronic Measurement and Instrumentation*, 2017, 31(3): 443-447.

作者简介



郑台台, 2021 年于中国计量大学获得学士学位, 现为中国计量大学硕士研究生, 主要研究方向为坐姿健康监测。

E-mail: 1833764534@qq.com



Zheng Taitai received his B.Sc. degree from China Jiliang University in 2021. He is currently a master student at China Jiliang University. His main research direction is sitting posture health monitoring.

姚燕(通信作者), 2008 年于浙江大学获得博士学位, 现为中国计量大学计量测试工程学院副教授, 主要研究方向为近红外光谱检测、生物质特性分析和生物质能源转化与利用。

E-mail: yaoyan@cjlu.edu.cn

Yao Yan (Corresponding author) received her Ph.D. degree from Zhejiang University in 2008. She is currently an associate professor at China Jiliang University, with a main research focus on near-infrared spectroscopy detection, biomass characteristic analysis, and biomass energy conversion and utilization.